

7-15-2024

A Deep Fuzzy Classifier Based on Feature Transform and Reconstruction

Rui Yin

School of Control Science and Engineering, Dalian University of Technology, Dalian 116023, China,
yinrui@mail.dlut.edu.cn

Wei Lu

School of Control Science and Engineering, Dalian University of Technology, Dalian 116023, China,
luwei@dlut.edu.cn

Jianhua Yang

School of Control Science and Engineering, Dalian University of Technology, Dalian 116023, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

A Deep Fuzzy Classifier Based on Feature Transform and Reconstruction

Abstract

Abstract: To obtain a classifier with good classification accuracy and interpretability, a deep fuzzy classifier based on feature transform and reconstruction (FR-DFC) is proposed. In FR-DFC, several fuzzy systems (FT_FS) for feature transform and a multi-prototype fuzzy classification system (MPRFD_FS) are stacked together to realize the classification process of the model, based on the hierarchically stacked thought originated from deep learning. Specifically, the stacked FT_FSs explore the hidden features in the data by transferring data from the original data space to the high-level feature space. MPRFD_FS, on the other hand, implements classification based on multiple prototypes that characterize the distribution of classifications in the high-level feature space. In addition, the proposed FR-DFC uses several fuzzy systems (RE_FS) for feature reconstruction to establish the mapping relationship between the high-level feature space and the original data space and establishes an understandably approximate fuzzy classifier in the original data space to ensure the interpretability of FR-DFC. Besides, FR-DFC utilizes gradient descent-based and end-to-end learning patterns to optimize the parameters of the model. The optimized objective function contains a classification loss function and a reconstruction loss function, which ensures both classification accuracy and interpretability of the model. Experimental results demonstrate that FR-DFC not only improves the classification accuracy but also possesses interpretability.

Keywords

fuzzy system, feature transform, classification, interpretability, reconstruction

Recommended Citation

Yin Rui, Lu Wei, Yang Jianhua. A Deep Fuzzy Classifier Based on Feature Transform and Reconstruction[J]. Journal of System Simulation, 2024, 36(7): 1546-1558.

基于特征传递与重构的深度模糊分类器

尹瑞, 卢伟*, 杨建华

(大连理工大学 控制科学与工程学院, 辽宁 大连 116023)

摘要: 为了获得具有良好的分类准确性同时兼具可解释性的模型, 提出了一种基于特征传递与重构的深度模糊分类器(deep fuzzy classifier based on feature transform and reconstruction, FR-DFC)。基于深度学习的层次堆叠思想, 数个用于特征传递的模糊系统(*fuzzy systems for feature transform, FT_FS*)和一个多原型模糊分类系统(*multi-prototype fuzzy classification system, MPRFD_FS*)堆叠在一起实现了模型的分類过程。其中, 数个堆叠的*FT_FS*将数据从原始数据空间传递到高层特征空间中來探索数据中隐含的特征信息。*MPRFD_FS*则依据多个描述高层特征空间中类的分布特征的原型来实现分类。另一方面, 利用多个用于特征重构的模糊系统(*fuzzy systems for feature reconstruction, RE_FS*)建立高层特征空间与原始数据空间的映射关系, 并在原始数据空间中建立了一个便于理解的近似模糊分类器来保证FR-DFC具有可解释性。采用基于梯度下降和端到端的学习方式来优化模型的参数。优化的目标函数包含了分类损失函数和重构损失函数, 能够同时保证模型的分類准确性和可解释性。实验结果表明: 该分类器在提升分类准确性的同时兼具可解释性。

关键词: 模糊系统; 特征传递; 分类; 可解释性; 重构

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2024)07-1546-13

DOI: 10.16182/j.issn1004731x.joss.23-0430

引用格式: 尹瑞, 卢伟, 杨建华. 基于特征传递与重构的深度模糊分类器[J]. 系统仿真学报, 2024, 36(7): 1546-1558.

Reference format: Yin Rui, Lu Wei, Yang Jianhua. A Deep Fuzzy Classifier Based on Feature Transform and Reconstruction[J]. Journal of System Simulation, 2024, 36(7): 1546-1558.

A Deep Fuzzy Classifier Based on Feature Transform and Reconstruction

Yin Rui, Lu Wei*, Yang Jianhua

(School of Control Science and Engineering, Dalian University of Technology, Dalian 116023, China)

Abstract: To obtain a classifier with good classification accuracy and interpretability, a deep fuzzy classifier based on feature transform and reconstruction (FR-DFC) is proposed. In FR-DFC, several fuzzy systems (*FT_FS*) for feature transform and a multi-prototype fuzzy classification system (*MPRFD_FS*) are stacked together to realize the classification process of the model, based on the hierarchically stacked thought originated from deep learning. Specifically, the stacked *FT_FS*s explore the hidden features in the data by transferring data from the original data space to the high-level feature space. *MPRFD_FS*, on the other hand, implements classification based on multiple prototypes that characterize the distribution of classifications in the high-level feature space. In addition, the proposed FR-DFC uses several fuzzy systems (*RE_FS*) for feature reconstruction to establish the mapping relationship between the high-level feature space and the original data space and establishes an understandably approximate fuzzy classifier

收稿日期: 2023-04-12 修回日期: 2023-06-05

基金项目: 国家自然科学基金(62073056, 61876029); 辽宁省应用基础研究计划(2023JH2/101300207); 大连市重点领域创新团队项目(2021RT14)

第一作者: 尹瑞(1991-), 男, 博士生, 研究方向为模糊模型及其应用。E-mail: yinrui@mail.dlut.edu.cn

通讯作者: 卢伟(1976-), 男, 教授, 博导, 博士, 研究方向为计算智能和模糊系统。E-mail: luwei@dlut.edu.cn

in the original data space to ensure the interpretability of FR-DFC. Besides, FR-DFC utilizes gradient descent-based and end-to-end learning patterns to optimize the parameters of the model. The optimized objective function contains a classification loss function and a reconstruction loss function, which ensures both classification accuracy and interpretability of the model. Experimental results demonstrate that FR-DFC not only improves the classification accuracy but also possesses interpretability.

Keywords: fuzzy system; feature transform; classification; interpretability; reconstruction

0 引言

利用深度学习^[1-2]技术来实现一个具有较高性能的模糊系统^[3-4]是近几年模糊研究领域的一个热点。其中, 广泛应用于数值分类任务的深度模糊系统^[5-8]是一个典型的代表。

深度模糊系统是借鉴深度学习策略构造的具有层连接结构的多层模糊模型。这些深度模糊系统的基础构造块(子模糊系统)一般采用 TSK (takagi-sugeno-kang)^[9]、WM (wang-mendel)^[10]等模糊模型。文献[11]通过顺序地堆叠多个零阶 TSK 模糊系统建立了一个深度 TSK 模糊分类器(deep TSK fuzzy classifier, D-TSK-FC)。D-TSK-FC 借助前一个子模糊系统的预测结果来改变原始空间中的数据分布而使数据更加可分。基于 D-TSK-FC, 一些类似的深度模糊分类器被提出^[12-13]。例如, 文献[14]提出了一个融入了对抗学习思想的(adversarial TSK classifiers, TSKa)模糊系统并利用它实现了深度模糊分类器(deep fuzzy classifier by stacking TSKa, DSA-FC)。在最近的一些研究中, 也提出了一些新颖的深度模糊模型。文献[15]依据层到层的结构实现了一个深度模糊分类器(deep fuzzy rule-based classification system, DFRBCS)。这个分类器的每一层包含多个并列的改进的 WM 模糊系统。上述研究通过堆叠多个子模糊分类器获得了相比单个子模糊分类器具有更好分类准确性的深度模糊分类器。但是上述模型缺乏对子模糊系统特征传递能力的研究, 使得它们的分类准确性与深度学习模型相比还有一定的差距。为此, 文献[16]提出一个具有特征传递能力的深度模糊分类器(deep fuzzy system with nonlinear fuzzy feature

transform, NFFT-DFSC)。NFFT-DFSC 由多个具有特征传递能力的模糊系统和一个具有决策能力的模糊系统堆叠组成, 这使得深度模糊模型具有了如同深度学习模型一样的特征学习能力。

然而, 在追求高的分类准确性的同时, 这些深度模糊模型的可解释性也随着模型深度的增加而下降。特别是在一些深度模糊分类器中, 子分类器的输入包含前一层的分类结果或者是一些不具有明确物理意义的隐含特征。为了使深度模糊分类器具有理想的分类性能和可解释性, 本文提出了一种基于特征传递和重构的深度模糊分类器(deep fuzzy classifier based on feature transform and reconstruction, FR-DFC)。在 FR-DFC 中, 数个堆叠的 FT_FS(fuzzy systems for feature transform)从数据中获得隐含的特征, MPRFD_FS(multi-prototype fuzzy classification system)则在高层特征空间中建立了数据和类别的映射关系。这使得 FR-DFC 如同多层神经网络一样具有特征学习能力, 从而保证所提出的模型具有好的分类性能。同时, 在 FR-DFC 中, 每个 FT_FS 对应一个 RE_FS(fuzzy systems for feature reconstruction), 用来将 FT_FS 学习的隐含特征空间中的数据重构回其相应的输入特征空间中。利用多个 RE_FS 能够将高层特征空间中的数据逐层地重构到原始空间中。同时, 优化过程中, 重构的损失函数使得重构的数据尽可能的近似原始数据, 也就是说能够约束特征传递过程保留数据中的主要信息。因此, 本文能够建立高层特征空间和原始数据空间的映射关系, 并在原始数据空间中建立一个近似的分类模型用于 FR-DFC 的分类过程的可解释性分析。

1 基于规则的模糊映射系统与多原型模糊分类系统

1.1 基于规则的模糊映射系统

在数据处理中, 将数据从 n 维的特征空间转移到 M 维的特征空间有利于探索数据中的信息。为此, 基于规则的模糊系统被用来建立特征空间之间的映射关系。首先, 将 n 维的特征空间分割为 M 个子空间, 并利用子空间的中心点(原型) $\mathbf{s}_j = [s_1^j, s_2^j, \dots, s_n^j]^T \in \mathbb{R}^{n \times 1}$ 来描述其结构特征。依据这 M 个原型, 一个具有 M 条规则的模糊映射模型被建立, 其规则形式为

$$R_j: \text{if } \mathbf{x} = A_j, \text{ then } \gamma_j = \sum_{g=1}^n a_g^j x_g + a_0^j \quad (1)$$

式中: \mathbf{x} 为 n 维特征空间中的样本点, $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$; A_j 为依据原型 \mathbf{s}_j 构造的模糊集, $j = 1, 2, \dots, M$; γ_j 为关于数据 \mathbf{x} 的线性函数; $a_0^j, a_1^j, \dots, a_n^j$ 为规则 R_j 的后件参数。通过 M 条规则, 数据 \mathbf{x} 将会被转换到 M 维的特征空间中, $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \rightarrow \mathbf{z} = [z_1, z_2, \dots, z_M]^T$ 。具体来说, 根据第 j 条规则 R_j 可以获得样本在 M 维空间中的第 j 个维度上的特征值 z_j , 计算过程如式(2)和(3)所示。

$$z_j = \frac{\mu_{A_j}(\mathbf{x})}{\sum_{j=1}^M \mu_{A_j}(\mathbf{x})} \gamma_j = \frac{\mu_{A_j}(\mathbf{x})}{\sum_{j=1}^M \mu_{A_j}(\mathbf{x})} \left(\sum_{g=1}^n a_g^j x_g + a_0^j \right) \quad (2)$$

$$\mu_{A_j}(\mathbf{x}) = \exp \left(- \sum_{g=1}^n \frac{(x_g - s_g^j)^2}{2(\sigma_g^j)^2} \right) \quad (3)$$

式中: $\mu_{A_j}(\mathbf{x})$ 为数据 \mathbf{x} 相对于模糊集 A_j 的高斯隶属度; σ_g^j 为对应的高斯函数的标准差。可以发现, 上述模糊系统是 n 维特征空间与 M 维的特征空间的一种映射关系。因此, 它能够实现样本在空间之间的转移, 从而探索数据所具有的隐含信息。例如, 当新的空间的维度 M 小于原始空间维度 n 时, 模糊系统(1)实现了数据降维, 能够获得数据所具有的主要特征。另一方面, 当空间的维度 $M > n$ 时, 模糊系统(1)则实现了数据升维。在所

提出的深度模糊分类器 FR-DFC 中, 本文利用上述基于规则的模糊映射系统实现了用于特征传递的模糊系统 FT_FS 与用于重构的模糊系统 RE_FS 来实现数据在两个特征空间之间的转移。

1.2 多原型模糊分类系统

在分类任务中, 最直观的分类方法是对比待分类数据和代表类别特征的原型的相似程度。与此同时, 通过多个原型能够更好地描述一个类, 例如, 利用 N_k 个原型 $\mathbf{v}_1^k, \mathbf{v}_2^k, \dots, \mathbf{v}_{N_k}^k$ 来描述第 k 类数据的分布特点。因此, 在一个 K 分类任务中, 依据每个类别的原型, 建立一个具有 K 条规则的模糊分类模型, 其形式如下:

$$R_k: \text{if } \mathbf{x} \text{ is } B_1^k \text{ or } B_2^k \text{ or } \dots \text{ or } B_{N_k}^k, \\ \text{then } \mathbf{x} \text{ belongs to class } L_k \text{ with } \bar{\kappa}_k \quad (4)$$

式中: L_k 为第 k 类的标签, $k = 1, 2, \dots, K$; B_m^k 为依赖于第 m 个原型 \mathbf{v}_m^k 建立的关于第 k 类数据的模糊集, $m = 1, 2, \dots, N_k$ 。利用式(4), 能够获得样本 $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^{n \times 1}$ 属于第 k 类的最大可能性 $\bar{\kappa}_k$, 进而实现分类任务。为此, 本文利用高斯隶属度函数计算出样本与每个类原型的相似程度:

$$\mu_{B_m^k}(\mathbf{x}) = \exp \left(- \sum_{g=1}^n \frac{(x_g - v_{m,g}^k)^2}{2(\psi_{m,g}^k)^2} \right) \quad (5)$$

式中: 高斯隶属度函数的中心 $v_{m,g}^k$ 是原型 \mathbf{v}_m^k 的第 g 维的变量值; $\psi_{m,g}^k \in \Psi_m^k$, 为对应的高斯隶属度函数标准差。随后, 依据所有的 $\mu_{B_m^k}(\mathbf{x})$ 计算样本与每个类的相似性:

$$\bar{\kappa}_k = \kappa_k / \sum_{q=1}^K \kappa_q \quad (6)$$

$$\kappa_k = \max \left\{ \mu_{B_1^k}(\mathbf{x}), \mu_{B_2^k}(\mathbf{x}), \dots, \mu_{B_{N_k}^k}(\mathbf{x}) \right\} \quad (7)$$

式中: $\bar{\kappa}_k$ 为样本属于类别 L_k 的归一化后的可能性; κ_k 表明样本与第 k 类的相似性由 N_k 个原型中最相近的原型来衡量。根据式(8), 样本 \mathbf{x} 将会被分配到具有最大激活程度的第 q 类中:

$$q = \arg \max_{k=1, 2, \dots, K} \bar{\kappa}_k \quad (8)$$

2 基于特征传递与重构的深度模糊分类器

本文基于一个 K 分类任务介绍深度模糊分类器 FR-DFC 的结构和学习过程。所使用的训练数据是一个归一化后的 n 维有标签的数据集 $D = \{(\mathbf{x}_i, \ell_i) | i = 1, 2, \dots, P\}$ 。其中: \mathbf{x}_i 为数据集中第 i 个样本, $\mathbf{x}_i = [x_1^i, x_2^i, \dots, x_n^i]^T \in [0, 1]^{n \times 1}$; ℓ_i 为其对应的标签, $\ell_i \in \{L_1, L_2, \dots, L_K\}$ 。

2.1 FR-DFC 的搭建

如图 1 所示, 本文所提出的 FR-DFC 包含 d ($d \geq 1$) 个 FT_FS, d 个 RE_FS 和一个 MPRFD_FS。其中, d 个 FT_FS 通过 BN (batch normalization)^[17] 运算和 sigmoid 函数顺序连接在一起构成模型的特征传递网络。在这一堆叠的网络结构中, 规则形式如式(1)所示的 FT_FS 实现了输入数据的特征传递, 并利用 BN 运算和 sigmoid 函数将数据压缩到单位隐含特征空间中。对于第 l 个 FT_FS 与其对应的 BN 运算和 sigmoid 函数而言, 它们通过式(9)~(12)实现了 $\hat{\mathbf{x}}_i^{l-1}$ (输入数据) 到 $\hat{\mathbf{x}}_i^l$ (输出数据) 的特征传递。

$$\hat{x}_{i,j}^l = \frac{1}{1 + \exp(-BN(z_{i,j}^l))} \quad (9)$$

$$BN(z_{i,j}^l) = \left(\rho_j^l \frac{z_{i,j}^l - b_j^l}{\sqrt{(\delta_j^l)^2 + \varepsilon}} + \beta_j^l \right) \quad (10)$$

$$z_{i,j}^l = \frac{\mu_{A_j^l}(\hat{\mathbf{x}}_i^{l-1})}{\sum_{t=1}^{M_l} \mu_{A_t^l}(\hat{\mathbf{x}}_i^{l-1})} \left(\sum_{g=1}^{M_{l-1}} a_{j,g}^l \hat{x}_{i,g}^{l-1} + a_{j,0}^l \right) \quad (11)$$

$$\mu_{A_j^l}(\hat{\mathbf{x}}_i^{l-1}) = \exp \left(- \sum_{g=1}^{M_{l-1}} \frac{(\hat{x}_{i,g}^{l-1} - s_{j,g}^l)^2}{2(\sigma_{j,g}^l)^2} \right) \quad (12)$$

式中: M_{l-1} 为第 $l-1$ 个隐含特征空间的维数; 输入数据 $\hat{\mathbf{x}}_i^{l-1} = [\hat{x}_{i,0}^{l-1}, \dots, \hat{x}_{i,M_{l-1}}^{l-1}]$ 为样本 \mathbf{x}_i 经过前 $l-1$ 个 FT_FS 及其对应的 BN 运算和 sigmoid 函数后获得隐含特征空间中的数据; $\hat{x}_{i,g}^{l-1}$ 为其第 g 个维度的特征值, $g=1, 2, \dots, M_{l-1}$; $\hat{x}_{i,j}^l$ 为特征传递过程输出结果 $\hat{\mathbf{x}}_i^l$ 的第 j 个维度的特征值, $j=1, 2, \dots, M_l$, 其中 M_l 为第 l 个 FT_FS 的规则数量(第 l 个隐含特征空间维度); $BN(\cdot)$ 为 BN 运算; b_j^l 和 δ_j^l 为由训练数据获得的均值和标准差; ρ_j^l 和 β_j^l 为用来实现缩放和偏移的可训练参数; $\varepsilon = 1 \times 10^{-8}$, 为一个用来避免除数为 0 的常量。

经过 d 个堆叠的 FT_FS 及其对应的 BN 运算和 sigmoid 函数后, 输入数据 \mathbf{x}_i 被转换成高层隐含特征空间数据 $\hat{\mathbf{x}}_i^d$ 。随后, 隐变量 $\hat{\mathbf{x}}_i^d$ 作为多原型模糊决策系统 MPRFD_FS 的输入来实现分类。由 1.2 节可知, 样本 \mathbf{x}_i 属于第 k 个类的概率 κ_i^k 可以利用隐变量 $\hat{\mathbf{x}}_i^d$ 与各个类别的原型的相似程度得到。最终, 利用式(8)为样本分配预测的类标签。

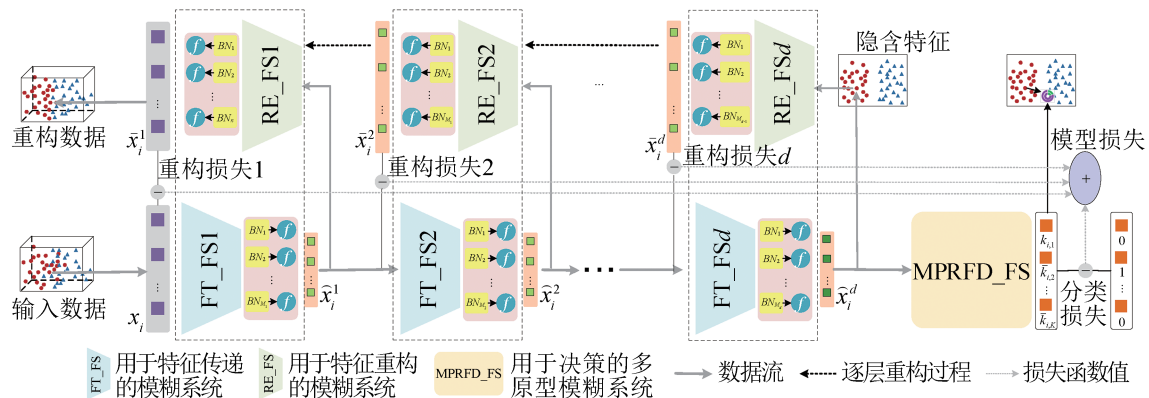


图1 FR-DFC 的结构图

Fig. 1 Architecture of FR-DFC

<http://www.china-simulation.com>

同时,为了保证模型的可解释性,FR-DFC引入了特征重构环节。如图1所示,每个用于特征传递的FT_FS及其对应的BN运算和sigmoid函数对应一个用于特征重构的RE_FS及其对应的BN运算和sigmoid函数。对于第 l 个RE_FS及其对应的BN运算和sigmoid函数而言,本文建立了从第 l 个特征学习过程的输出空间到输入空间的映射并通过损失函数的约束确保重构数据与输入数据的相似性。这也保证了特征传递过程获得的隐含特征具有输入数据的主要特征。具体来讲,第 l 个规则形式如图1所示的RE_FS及其对应的BN运算和sigmoid函数所对应的特征重构过程如式(13)~(16)所示。

$$\bar{x}_{i,r}^l = \frac{1}{1 + \exp(-\text{BN}(\hat{z}_{i,r}^l))} \quad (13)$$

$$\text{BN}(\hat{z}_{i,r}^l) = \left(\hat{\rho}_r^l \frac{\hat{z}_{i,r}^l - \hat{b}_r^l}{\sqrt{(\hat{\delta}_r^l)^2 + \varepsilon}} + \hat{\beta}_r^l \right) \quad (14)$$

$$\hat{z}_{i,r}^l = \frac{\mu_{\hat{A}_r}(\hat{\mathbf{x}}_i^l)}{\sum_{i=1}^{M_{l-1}} \mu_{\hat{A}_r}(\hat{\mathbf{x}}_i^l)} \left(\sum_{j=1}^{M_l} \hat{a}_{r,j}^l \hat{x}_{i,j}^l + \hat{a}_{r,0}^l \right) \quad (15)$$

$$\mu_{\hat{A}_r}(\hat{\mathbf{x}}_i^l) = \exp \left(- \sum_{j=1}^{M_l} \frac{(\hat{x}_{i,j}^l - \hat{s}_{r,j}^l)^2}{2(\hat{\sigma}_{r,j}^l)^2} \right) \quad (16)$$

式中: $\hat{\mathbf{x}}_i^l = [\hat{x}_{i,0}^l, \dots, \hat{x}_{i,M_l}^l]$ 为样本 \mathbf{x}_i 经过第 l 个 FT_FS 与其对应的 BN 运算和 sigmoid 函数后获得的隐含特征空间数据; $\bar{x}_{i,r}^l$ 为特征重构过程输出结果 $\bar{\mathbf{x}}_i^l$ 的第 r ($r = 1, 2, \dots, M_{l-1}$) 个维度的特征值。可以发现,特征传递过程使得 M_{l-1} 维的输入数据 $\hat{\mathbf{x}}_i^{l-1}$ 传递到 M_l 维的输出 $\hat{\mathbf{x}}_i^l$, 其中 $M_{l-1} \geq M_l$ 。特征重构过程则实现了一个对称运算,将 M_l 维的输出 $\hat{\mathbf{x}}_i^l$ 还原成 M_{l-1} 维的数据 $\bar{\mathbf{x}}_i^l$ 。特征重构过程中 RE_FS 的规则数量由对应的特征传递过程中 FT_FS 的输入数据维度决定。同时,为了使重构数据 $\bar{\mathbf{x}}_i^l$ 能够接近原有的输入数据 $\hat{\mathbf{x}}_i^{l-1}$, BN 运算和 sigmoid 函数将重构数据 $\bar{\mathbf{x}}_i^l$ 压缩到与输入数据对应的单位空间中。每个

特征重构环节在其对应的特征传递过程的输出空间和输入空间中建立了映射关系。通过逐层的特征重构环节,能够探索高层隐含特征和原始数据空间的关系。从而实现在原始空间中建立分类过程的近似语义模型来确保模型的可解释性。

2.2 FR-DFC 参数的学习

为了使提出的 FR-DFC 具有较好的分类准确性和重构能力,本文在归一化的有标签的数据集 $D = \{(\mathbf{x}_i, \ell_i) | i = 1, 2, \dots, P\}$ (分割为具有 F 个样本的训练集 D_{train} 和具有 $P-F$ 个样本的验证集 D_{valid}) 上对模型进行优化。在优化过程中,决定模型结构的超参数包括模型的深度 d , 各个隐含特征空间的维度 M_1, M_2, \dots, M_d , 模糊决策模型中每个类对应的原型数量 N_1, N_2, \dots, N_k , 将采用随机搜索算法^[18]进行优化。

在一组超参数下,模型中的可训练参数则采用 mini-batch 梯度下降(mini-batch gradient descent, MBGD)算法^[19]进行优化。其中,模型的可训练参数包括每个 FT_FS 及其对应的 BN 运算的可训练参数、每个 RE_FS 及其对应的 BN 运算的可训练参数,以及 MPRFD_FS 的可训练参数。以第 l 个 FT_FS 及其对应的 BN 运算为例,其可训练参数包括模糊系统的原型 $\mathbf{s}_1^l, \mathbf{s}_2^l, \dots, \mathbf{s}_{M_l}^l$, 标准差 $\sigma_1^l, \sigma_2^l, \dots, \sigma_{M_l}^l$ 和后件参数 $\{a_{1,0}^l, a_{1,1}^l, \dots, a_{1,M_{l-1}}^l\}, \dots, \{a_{M_r,0}^l, a_{M_r,1}^l, \dots, a_{M_r,M_{l-1}}^l\}$, BN 运算中的缩放系数 $\{\rho_1, \rho_2, \dots, \rho_{M_l}\}$ 和偏移系数 $\{\beta_1, \beta_2, \dots, \beta_{M_l}\}$ 。对于第 l 个 RE_FS 及其对应的 BN 运算,其可训练参数包括模糊系统的原型 $\hat{\mathbf{s}}_1^l, \hat{\mathbf{s}}_2^l, \dots, \hat{\mathbf{s}}_{M_{l-1}}^l$, 标准差 $\hat{\sigma}_1^l, \hat{\sigma}_2^l, \dots, \hat{\sigma}_{M_{l-1}}^l$ 和后件参数 $\{\hat{a}_{1,0}^l, \hat{a}_{1,1}^l, \dots, \hat{a}_{1,M_l}^l\}, \dots, \{\hat{a}_{M_{l-1},0}^l, \hat{a}_{M_{l-1},1}^l, \dots, \hat{a}_{M_{l-1},M_l}^l\}$, BN 运算中的缩放系数 $\{\hat{\rho}_1, \hat{\rho}_2, \dots, \hat{\rho}_{M_{l-1}}\}$ 和偏移系数 $\{\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_{M_{l-1}}\}$ 。对于 MPRFD_FS, 以第 k 个规则为例,可训练参数则包括第 k 类数据的原型 $\mathbf{v}_1^k, \mathbf{v}_2^k, \dots, \mathbf{v}_{N_k}^k$ 和相应的标准差 $\psi_1^k, \psi_2^k, \dots, \psi_{N_k}^k$ 。在这些参数的学习过程中,

首先参考文献[16]对这些参数进行初始化。随后, 在训练集上采用MBGD算法对模型的参数进行优化, 优化的目标函数为

$$Loss = \frac{\sum_{i=1}^{P_{bs}} \left(-\sum_{k=1}^K (y_i^k \times \ln(\bar{\kappa}_i^k)) + \sum_{l=1}^d \frac{1}{M_{l-1}} \sum_{j=1}^{M_{l-1}} (\hat{x}_{i,j}^{l-1} - \bar{x}_{i,j}^l)^2 \right)}{P_{bs}} \quad (17)$$

式中: y_i^k 为数据所对应的真实标签的 one-hot 编码; P_{bs} 为每个 mini-batch 中的样本数量; $-\sum_{k=1}^K (y_i^k \times \ln(\bar{\kappa}_i^k))$ 为模型的分损失函数, 用来保证模型能够给出准确的分类预测; $\sum_{l=1}^d \frac{1}{M_{l-1}} \sum_{j=1}^{M_{l-1}} (\hat{x}_{i,j}^{l-1} - \bar{x}_{i,j}^l)^2$ 为特征重构损失函数, 用来实现隐含特征空间中数据能够准确的还原成上一层隐含特征空间中对应的数据。其中, M_{l-1} 表示第 $l-1$ 个隐含特征空间的维度。当 $l=1$ 时, $M_0=n$, $\hat{x}_{i,j}^0=x_j^i$ 。通过最小化目标函数, 本文希望提出的模型在分类和重构上同时具有较好的表现。需要说明的是在每次参数更新时, 用于特征传递的模糊系统 FT_FS 和用于特征重构的模糊系统 RE_FS 的原型以及模糊决策系统 MPRFD_FS 类的原型的更新范围均被限制在其所对应的单位特征空间中。在每轮模型更新后, 模型的性能将会在验证集上进行评估。如果当前模型在验证集上的损失函数值小于候选模型在验证集上的损失函数值, 则将当前模型设置为新的候选模型。因此, 在训练完成后, 本文将获得一个在验证集上具有最小损失函数值的模型, 并利用这个最优模型来完成对未知数据的分类任务。

2.3 FR-DFC 的复杂度分析

本文主要从模型的计算复杂度和需要训练的参数数量来分析模型的复杂度。其中, 模型的计算复杂度主要包含分类过程中特征学习和决策的计算复杂度以及重构过程中特征重构的计算复杂度。对于第 l 个 FT_FS 及其所对应的 BN 运算和 sigmoid 函数, 它的计算复杂度近似为 $O(8M_l M_{l-1} +$

$4M_l)$ 。因此, d 个 FT_FS 所实现的特征学习的计算复杂度近似为 $O\left(\sum_{l=1}^d (8M_l M_{l-1} + 4M_l)\right)$ 。对于 MPRFD_FS 所实现的决策过程的计算复杂度则近似为 $O\left(\sum_{k=1}^K (6M_d N_k)\right)$ 。由于特征学习与重构的过程是对称的, 因此模型的特征重构过程的计算复杂度可以近似的看作是 $O\left(\sum_{l=1}^d (8M_l M_{l-1} + 4M_{l-1})\right)$ 。当仅利用模型实现分类决策时, 单个样本的决策过程的计算复杂度为 $O\left(\sum_{l=1}^d (8M_l M_{l-1} + 4M_l) + \sum_{k=1}^K (6M_d N_k)\right)$ 。当在分类决策的同时将样本重构回原始空间实现可解释性分析时, 其总体的计算复杂度近似为 $O\left(\sum_{l=1}^d (16M_l M_{l-1} + 4M_l + 4M_{l-1}) + \sum_{k=1}^K (6M_d N_k)\right)$ 。对于模型的参数数量而言, 特征学习部分所具有的可训练参数为 d 个 FT_FS 的原型, 标准差以及 BN 运算中的参数, 其数量为 $\sum_{l=1}^d 3(M_l M_{l-1} + M_l)$ 。类似的, 特征重构部分所具有的可训练参数数量为 $\sum_{l=1}^d 3(M_l M_{l-1} + M_{l-1})$ 。决策部分的可训练参数则主要是类原型及其标准差, 其数量为 $\sum_{k=1}^K 2M_d N_k$ 。本文可以发现, 模型的复杂度主要由各个特征空间的维度和模糊子系统数量决定。其中, 随着深度模糊分类器中模糊子系统数量的增加, 模型变得更加复杂。

3 实验结果与分析

3.1 FR-DFC 的分类与重构分析

人工数据集实验利用如图 2 所示的三维的 Moon 数据集(3D-Moon)来分析模型的工作原理, 展示其分类与重构过程。

图 2 中类别 I 和类别 II 分别具有 500 个分布在 $[0, 1]^{3 \times 1}$ 空间中的样本点。为了方便说明, 本文预先设定模型的深度为 1, 对应的隐含特征空间维度为 2, MPRFD_FS 中每个类的原型数量分别为 1。确定模型结构后, 本文从数据集中随机选择 80% 的样本作为训练数据, 剩余 20% 的样本作为测试集, 并在训练数据上采用十折交叉验证法验证模型性能。每次实验中利用 2.2 章节中的学习方法来优化模型中的可训练参数。实验中 mini-batch 的样本数量设为 64。图 3 为所获得的一个模型在测试集上的实验结果。







图 2 3D-Moon 数据集
Fig. 2 3D-Moon dataset




(a) 原始数据与 FT_FS 原型



(b) 特征数据与 MPRFD_FS 原型



(c) 特征数据与 RE_FS 原型



(d) 重构数据与重构 MPRFD_FS 原型

图 3 3D-Moon 测试集实验结果
Fig. 3 Experimental results of 3D-Moon dataset on testing set

图3(a)~(b)展示了模型在测试集上的分类过程。原始的测试集数据经过FT_FS及其对应的BN运算和sigmoid函数后转变到了一个新的二维隐含特征空间中。在图3(b)所示的新的特征空间中,原有数据中的嵌套部分消失,表现出线性可分的特点。根据MPRFD_FS可以为样本分配相应的类标签。实验结果表明,经过特征传递后,数据更加有利于分类。图3(c)~(d)展示了模型在测试集上的重构过程。二维隐含特征空间中的数据 and 分类原型经过RE_FS及其对应的BN运算和sigmoid函数后映射到原始的数据空间中。图3(d)中记录了重构回原始空间中的测试数据和MPRFD_FS中分类原型的分布。可以发现,图3(d)中重构回原始空间中的测试数据与图3(a)中的未处理的测试数据相比具有相似性,保留了数据在空间中的分布趋势,这也反映出隐含特征空间中的数据保留了原始数据的主要信息。


3.2 FR-DFC的可解释性分析

作为一个分类器,可解释性有助于用户理解其决策过程。在所提出的模型中,通过在原始数据空间中重构模型的决策过程,从而建立一个用于理解的近似分类模型来保证FR-DFC的可解释性。


本文以人工数据集3D-Moon为例来分析模型的可解释性。如图4所示,图中渐变橙色星形表示:当隐含特征空间中 \hat{x}_1 值固定, \hat{x}_2 值增长时,对应于原始空间中 \bar{x}_1 值增大, \bar{x}_2 与 \bar{x}_3 减小,但是 \bar{x}_2 与 \bar{x}_3 的变化较小可以被忽略。图4中渐变蓝色星形展示出:当 \hat{x}_2 值固定, \hat{x}_1 值增长时,对应于原始空间中 \bar{x}_1 减小, \bar{x}_2 、 \bar{x}_3 增大。基于此,可以建立特征空间中各个维度与原始空间各个维度的关系。因此,在特征空间中建立的分类模型,

$$R_1: \text{if } \hat{\mathbf{x}} \text{ is } B_1^1 (\hat{x}_1 \text{ is large (0.61)}, \hat{x}_2 \text{ is large (0.83)}), \\ \text{then } \mathbf{x} \text{ belongs to class } L_1 \text{ with } \bar{\kappa}_1$$

$$R_2: \text{if } \hat{\mathbf{x}} \text{ is } B_1^2 (\hat{x}_1 \text{ is small (0.03)}, \hat{x}_2 \text{ is small (0.44)}), \\ \text{then } \mathbf{x} \text{ belongs to class } L_2 \text{ with } \bar{\kappa}_2$$



(a) 隐含特征空间



(b) 原始数据空间

图4 可解释性分析

Fig. 4 Analysis of interpretability

可以被表示成原始空间中的近似分类模型,

$$R_1: \text{if } \bar{\mathbf{x}} = B_1^1 \left(\begin{array}{l} (\bar{x}_1 \text{ is small (0.63)}, \bar{x}_2 \text{ is large (0.56)}, \\ \bar{x}_3 \text{ is large (0.65)}) \\ \text{and } (\bar{x}_1 \text{ is small (0.63)}) \end{array} \right),$$

then \mathbf{x} belongs to class L_1 with $\bar{\kappa}_1$

$$R_2: \text{if } \bar{\mathbf{x}} = B_1^2 \left(\begin{array}{l} (\bar{x}_1 \text{ is large (0.91)}, \bar{x}_2 \text{ is small (0.11)}, \\ \bar{x}_3 \text{ is small (0.12)}) \\ \text{and } (\bar{x}_1 \text{ is large (0.91)}) \end{array} \right),$$

then \mathbf{x} belongs to class L_2 with $\bar{\kappa}_2$

$\bar{x}_1, \bar{x}_2, \bar{x}_3$ 与 x_1, x_2, x_3 表示了相同的数据空间。因此,通过重构在原始数据空间中建立了模型

FR-DFC的决策过程的近似分类模型，从而保证了模型的可解释性。当模型的深度增加时，可以利用多个RE_FS及其对应的BN运算和sigmoid函数来建立高层特征空间到原始空间的映射关系。通过逐层重构，将高层特征空间中的数据重构到原始空间中并建立FR-DFC的决策过程的近似分类模型来保证FR-DFC的可解释性。

3.3 公开数据集实验

3.3.1 对比实验说明

为了验证所提出模型的分类性能，本文在表1所示的11个公开数据集上进行了对比实验，所采用的对比分类器如表2所示。表2中，RF(random forest)、GSVM(gaussian support vector machine)、MLP(multilayer perceptron)是较为常用的机器学习算法，TSK-0、TSK-1属于传统的模糊分类算法，SF-DNN(sequential fuzzy deep neural network)、HFF-DNN(hierarchical fused fuzzy deep neural network)是将模糊逻辑融入神经网络中构成的模糊神经网络分类器，D-TSK-FC、DFRBCS、DSA-FC、FAT-DSA-FC(fast DSA-FC)则是有代表性的深度模糊分类器。

表1 公开数据集总结
Table 1 Publicly available datasets

数据集	特征数	样本数	类别	来源
Kddcup99(KDD)	41	494 019	23	KEEL
Musk(v2)(MUK)	166	6 598	2	UCI
Mushroom(MUM)	21	8 124	2	UCI
Adult(ADU)	14	48 842	2	UCI
Magic04(MAG)	10	19 020	2	KEEL
Electricity pricing(ELE)	8	45 312	2	UCI
Skin segmentation(SKI)	3	245 057	2	UCI
Seismic bumps(SEI)	18	2 584	2	UCI
Pageblocks(PAG)	10	5 473	5	KEEL
Thyroid(THY)	21	7 200	3	KEEL
Miniboone(MBO)	50	130 064	2	UCI

表2 对比实验分类器

分类器	描述
RF	随机森林 ^[20]
GSVM	高斯核支持向量机 ^[21]
MLP	全连接神经网络 ^[22]
TSK-0	零阶TSK分类器
TSK-1	一阶TSK分类器
SF-DNN	顺序模糊深度神经网络 ^[23]
HFF-DNN	层次融合的模糊深度神经网络 ^[24]
D-TSK-FC	基于零阶TSK的深度模糊分类器 ^[11]
DFRBCS	基于WM的深度模糊分类器 ^[15]
DSA-FC	基于TSKa的深度模糊分类器 ^[14]
FAT-DSA-FC	快速学习的DSA-FC ^[25]

对比实验分为3个部分。第1部分对比实验将所提出模型FR-DFC与RF、GSVM、MLP、TSK-0、TSK-1、SF-DNN和HFF-DNN做比较。实验中，在每个数据集上随机选择80%的样本作为训练数据，剩余20%的样本作为测试集，并在训练集上利用十折交叉法来验证分类器的性能。对于FR-DFC，本文采用随机搜索算法来优化模型的超参数。其中，模型的深度 d 的搜索范围为整数集合 $\{1, 2, \dots, 10\}$ 。隐含特征空间维度的搜索范围由上一层的隐含特征空间维度决定，以第 l 个隐含特征空间为例，搜索空间为整数集合 $\{2, 3, \dots, M_{l-1}\}$ ， M_{l-1} 是第 l 个FT_FS的输入数据维度(上一层隐含特征空间维度)。需要说明的是，当原始数据维度 $n > 16$ 时，第一个隐含特征空间维度的搜索空间定义为整数集合 $\{2, 3, \dots, 16\}$ 。否则搜索空间定义为 $\{2, 3, \dots, n\}$ 。MPRFD_FS中每个类的原型数量的搜索范围则是整数集合 $\{1, 2, \dots, 10\}$ 。另外，模型中的可训练参数依据2.2章节中的学习方法来优化，训练过程中mini-batch的样本数量 P_{bs} 也被作为超参数来优化，它的值在整数32到训练集数据数量之间搜索。表3给出了FR-DFC在所

有数据集上使用的超参数。对于这些经典的对比分类器, 它们的超参数或者参数也将被优化。

表3 第1部分对比实验中FR-DFC的超参数

Table 3 Hyper parameters of FR-DFC for the first group of comparison experiments

数据集	d	M_l	N_k	P_{bs}
KDD	2	14,11	9,1,8,7,7,7,6,3,3,9,6, 7,7,8,4,5,5,1,3,6,1,2,5	50 176
MUK	3	7,4,4	7,1	1 088
MUM	2	4,3	1,2	1 888
ADU	3	14,13,8	7,4	3 584
MAG	3	9,5,5	1,5	7 680
ELE	1	6	4,8	4 608
SKI	2	3,2	9,8	21 504
SEI	2	9,5	4,3	32
PAG	1	4	5,6,2,3,7	512
THY	2	13,9	5,8,4	704
MBO	2	10,2	3,7	10 240

第2部分与第3部分对比实验分析了FR-DFC与已有的深度模糊分类器D-TSK-FC、DFRBCS、DSA-FC和FAT-DSA-FC的分类性能。由于这些深度模糊分类器的代码未被公开, 它们的实验结果来源于它们各自被提出的文章中, 数据集则采用与表1中共有的部分数据集。同时, 依据它们不同的实验设置, 将FR-DFC与D-TSK-FC、DFRBCS、DSA-FC和FAT-DSA-FC分别进行比较。因此, 第2部分对比实验比较了FR-DFC、D-TSK-FC与DFRBCS, 数据集有KDD、MUK、MUM、ADU、MAG、ELE、SKI、SEI和PAG。实验中在每个数据集中随机选择75%的样本作为训练数据, 剩余25%的样本作为测试集。第3部分对比实验则比较了FR-DFC与DSA-FC、FAT-DSA-FC和DFRBCS, 数据集有KDD、MUK、MUM、ADU、MAG、SKI、SEI、PAG和THY。实验中采用分层的十折交叉验证来验证分类性能。表4~5分别为FR-DFC在第2部分和第3部分对比实验中使用的超参数。

表4 第2部分对比实验中FR-DFC的超参数

Table 4 Hyper parameters of FR-DFC for the second group of comparison experiments

数据集	d	M_l	N_k	P_{bs}
KDD	2	14,2	5,1,3,2,5,8,2,2, 4,5,4, 3,8,2,5,3,7,9,7,3,4,8,3	35 000
MUK	1	10	7,1	2 292
MUM	3	11,5,2	5,5	756
ADU	1	4	6,5	7 120
MAG	4	6,4,4,4	1,8	6 096
ELE	1	5	5,4	4 048
SKI	1	2	2,9	40 000
SEI	1	7	8,4	1 268
PAG	2	6,6	1,7,4,2,9	2 036

表5 第3部分对比实验中FR-DFC的超参数

Table 5 Hyper parameters of FR-DFC for the third group of comparison experiments

数据集	d	M_l	N_k	P_{bs}
KDD	1	5	4,5,6,8,1,4,7,6,2,6,4, 3,3,5,7,5,4,2,9,2,4,5,5	95 000
MUK	2	5,4	3,3,	2 548
MUM	5	15,5,5,4,3	6,8,	756
ADU	1	11	3,5,	22 480
MAG	3	4,4,4	5,4,	5 072
SKI	1	2	4,6,	30 000
SEI	4	7,7,5,4	4,6,	1 524
PAG	1	8	3,3,7,6,7	1 268
THY	2	14,6	5,2,6	1 012

3.3.2 实验结果分析

表6为第1部分对比实验中各个分类器在11个数据集的测试集上取得的平均分类准确率和对应的标准差。相比于3个常用的机器学习算法, 所提出的FR-DFC在8个数据集上取得了最好的平均分类准确率, 特别在样本维度高或者样本个数多的数据集MUK、ADU、ELE和MBO上获得了好的分类性能。同时, FR-DFC在样本个数多的KDD和SKI数据集上的平均分类准确率分别相同于GSVM和MLP。这说明了所提出的方法相比于这些常用的机器学习算法在一些高维或者大样本的数据集上具有较好的分类性能。相比于传统的

模糊分类器，FR-DFC的性能在11个数据集上均取得了较大的提升。例如，在KDD、MUK、ADU、ELE、SKI和MBO上，FR-DFC的平均分类准确率相比于TSK-0分别提高了126.5%、60.1%、13.7%、30.2%、25.4%和14.6%，相比于TSK-1则分别提高了98.2%、29.8%、11.1%、14.8%、10.3%和10.1%。这表明通过堆叠的结构，能够使模糊模型获得好的分类准确性。另一方面，相比于模糊神经网络分类器，FR-DFC的平均分类准确率在9个数据集上优于SF-DNN和HFF-DNN。

在MUM和SEI数据集上，所提出的深度模糊分类器与这2个模糊神经网络分类器具有相似的分类性能。上述结果表明，FR-DFC在一些分类任务中相比于模糊神经网络也具有明显的优势。这是因为FR-DFC通过堆叠用于特征传递的模糊模型和用于决策的模糊模型而具备了如同神经网络一样的特征传递能力。同时，借助于端到端的学习算法，使得模型能够从数据中学习模糊系统的参数，这也有助于提升模型性能。

表6 FR-DFC与经典分类器对比实验的分类准确率

分类器	RF	GSVM	MLP	TSK-0	TSK-1	SF-DNN	HFF-DNN	FR-DFC
KDD	98.4±0.1	99.9±0.0	98.8±0.0	44.1±3.9	50.4±2.1	98.9±0.1	98.2±0.0	99.9±0.0
MUK	89.7±0.5	94.3±0.4	98.5±0.3	61.7±6.5	76.1±6.1	97.7±0.7	97.8±0.6	98.8±0.6
MUM	99.7±0.3	100.0±0.0	100.0±0.0	78.8±28.7	98.4±1.5	100.0±0.0	99.9±0.1	100.0±0.0
ADU	82.2±0.3	83.7±0.3	84.2±0.0	74.7±0.2	76.4±0.2	83.5±0.1	84.3±0.1	84.9±0.2
MAG	79.0±1.4	85.4±0.1	86.0±0.7	75.1±0.6	76.4±0.5	83.1±0.5	84.5±0.6	86.5±1.1
ELE	77.6±0.4	79.4±0.0	78.9±0.1	61.5±0.2	69.8±0.2	76.1±0.5	77.0±0.3	80.1±1.0
SKI	98.9±0.1	99.5±0.0	99.7±0.1	79.5±0.3	90.4±0.4	98.0±0.0	98.4±0.1	99.7±0.1
SEI	93.1±0.1	93.1±0.1	93.1±0.1	91.4±0.1	92.7±2.0	93.4±0.1	93.4±0.1	93.4±0.0
PAG	95.6±0.2	94.5±0.3	93.6±0.4	85.3±0.7	90.2±0.7	93.4±0.8	93.6±0.1	96.3±0.0
THY	93.0±0.4	93.8±0.0	95.7±0.2	93.2±1.1	93.4±0.4	95.3±1.0	96.8±1.3	97.8±0.2
MBO	84.3±0.6	87.7±0.2	82.1±0.8	80.1±0.1	83.4±0.3	84.1±0.1	86.4±1.4	91.8±0.3

表7为第2部分对比实验中的3种深度模糊分类器在9个数据集的测试集上取得的平均分类准确率和对应的标准差。其中，D-TSK-FC和DFRBCS分别通过堆叠多个TSK子分类器和WM子分类器来获得了较好的分类性能。

从表7中可以看出，相比于这2种深度模糊分类器，FR-DFC在8个数据集上取得了最好的平均分类准确率。在SEI数据集上3种深度模糊分类器的性能接近。值得说明的是，在样本维度高或者样本个数多的数据集KDD、MUK、ADU、ELE和SKI上，FR-DFC的平均分类准确率相比于D-TSK-FC分别提高了75%、4.8%、7.8%、6.3%和4.1%，相比于DFRBCS则分别提高了1.3%、6%、1.6%、6.1%和0.3%。

表7 FR-DFC与D-TSK-FC和DFRBCS对比实验的分类准确率

分类器	D-TSK-FC	DFRBCS	FR-DFC
KDD	56.8	98.1	99.4
MUK	94.2	93.1	98.7
MUM	94.9	99.2	99.9
ADU	78.2	83.0	84.3
MAG	77.3	82.3	84.3
ELE	75.0	75.1	79.7
SKI	94.8	98.4	98.7
SEI	93.3	93.5	93.5
PAG	94.0	94.2	96.1

表8则提供了第3部分对比实验中的深度模糊分类器在9个数据集的测试集上取得的平均分类准确率和对应的标准差。其中，符号“—”表示分类

器在该数据集上的分类性能在其被提出的论文中未提供。相比于D-TSK-FC, DSA-FC引入对抗思想, 利用平滑的梯度信息来调整输入数据, 从而获得了更好的分类性能。FAT-DSA-FC通过梯度引导算法来改进DSA-FC的学习过程, 从而使模型获得更好的泛化能力。

表8 FR-DFC与DSA-FC, FAT-DSA-FC和DFRBCS
对比实验的分类准确率

Table 8 Classification accuracy of comparison experiments
between FR-DFC, DSA-FC, FAT-DSA-FC, and DFRBCS
%

分类器	DSA-FC	FAT-DSA-FC	DFRBCS	FR-DFC
KDD	63.2±0.7	63.1±0.5	—	99.1±0.3
MUK	92.3±0.2	91.6±0.4	—	97.1±1.6
MUM	100.0±0.0	—	99.7±0.2	100.0±0.0
ADU	92.7±0.1	93.1±0.1	—	86.7±0.5
MAG	83.5±0.1	—	83.9±0.9	84.8±1.3
SKI	93.8±0.0	93.7±0.0	—	99.1±0.4
SEI	94.7±0.1	—	93.4±0.0	93.4±0.0
PAG	93.5±0.3	—	94.9±1.0	96.6±0.8
THY	94.4±0.1	—	95.5±0.6	98.3±0.4

从表8中可以发现, 相比于DSA-FC, FR-DFC在6个数据集上取得了最好的平均分类准确率。在4个共有的数据集KDD、MUK、ADU和SKI上, FR-DFC则在其中3个数据集上获得了优于FAT-DSA-FC的表现。值得说明的是, 在样本维度高或者样本个数多的数据集KDD、MUK和SKI上, FR-DFC的平均分类准确率相比于DSA-FC分别提高了56.8%、5.2%和5.7%, 相比于FAT-DSA-FC则分别提高了57.1%、6%和5.8%。此外, 在ADU数据集上, FR-DFC的性能低于DSA-FC和FAT-DSA-FC。

表7~8的实验结果表明, 本文所提深度模糊分类器FR-DFC相比于上述深度模糊分类器具有更加优秀的分类准确性。这是因为分类器FR-DFC具有堆叠的特征传递模块, 能够获得更加适合分类的高层隐含特征。同时, FR-DFC采用MBGD和端到端的学习方法能够增强模型解决大样本或高维数据的分类任务的能力。

4 结论

本文提出的基于特征传递与重构的深度模糊分类器FR-DFC通过堆叠的数个用于特征传递的模糊模型和一个多原型模糊决策系统实现了模型的过程。同时, 利用FR-DFC中的重构模块建立了数据空间之间的映射关系。FR-DFC利用MBGD和端到端的方式优化模型参数使它的分类损失值和重构损失值都趋向于变小, 从而使模型具有较好的性能。在人工数据集实验中展示了模型的过程和特征重构过程, 并分析了模型的可解释性。公开数据集实验则通过对比实验表明, FR-DFC在分类准确性上具有很好的竞争力, 极大地提高了传统的模糊模型的性能, 相比于现有的深度模糊分类器也具有竞争力。在今后的研究将进一步延伸应用背景, 并考虑与不同的深度神经网络结合使模型能够更加适用于一些复杂的应用场景。

参考文献:

- [1] Roberts D A, Yaida S, Hanin B. The Principles of Deep Learning Theory: An Effective Theory Approach to Understanding Neural Networks[M]. Cambridge: Cambridge University Press, 2022.
- [2] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. 智能系统学报, 2019, 14(1): 1-19.
Hu Yue, Luo Dongyang, Hua Kui, et al. Overview on Deep Learning[J]. CAAI Transactions on Intelligent Systems, 2019, 14(1): 1-19.
- [3] 杨祯山, 岳文姣. 基于FCM聚类模糊神经网络的电梯交通模式识别[J]. 系统仿真学报, 2018, 30(4): 1433-1438, 1447.
Yang Zhenshan, Yue Wenjiao. Elevator Traffic Pattern Recognition with FCM Clustering Based Fuzzy Neural Network[J]. Journal of System Simulation, 2018, 30(4): 1433-1438, 1447.
- [4] 冯国亮, 卢伟, 杨建华. 用于时间序列数据建模的多模态模糊认知图[J]. 系统仿真学报, 2022, 34(3): 543-554.
Feng Guoliang, Lu Wei, Yang Jianhua. Modeling Time Series Using Multi-modality Fuzzy Cognitive Maps[J]. Journal of System Simulation, 2022, 34(3): 543-554.
- [5] Yazdanbakhsh O, Dick S. A Deep Neuro-fuzzy Network for Image Classification[EB/OL]. (2019-12-22) [2023-01-29]. <https://arxiv.org/abs/2001.01686>.
- [6] Wang Guanjin, Zhou Ta, Choi K S, et al. A Deep-

- ensemble-level-based Interpretable Takagi-sugeno-kang Fuzzy Classifier for Imbalanced Data[J]. IEEE Transactions on Cybernetics, 2022, 52(5): 3805-3818.
- [7] Zhou Ta, Wang Guanjin, Choi K S, et al. Recognition of Sleep-wake Stages by Deep Takagi-sugeno-kang Fuzzy Classifier with Random Rule Heritage[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2023, 7(5): 1458-1469.
- [8] Zhao Tao, Cao Hongyi, Dian Songyi. A Self-organized Method for a Hierarchical Fuzzy Logic System Based on a Fuzzy Autoencoder[J]. IEEE Transactions on Fuzzy Systems, 2022, 30(12): 5104-5115.
- [9] Chen Yang, Yang Jiaxiu, Li Chenxi. Design of Takagi Sugeno Kang Type Interval Type-2 Fuzzy Logic Systems Optimized with Hybrid Algorithms[J]. International Journal of Fuzzy Systems, 2023, 25(2): 868-879.
- [10] Zhai Yanwei, Lü Zheng, Zhao Jun, et al. Data-driven Inference Modeling Based on an On-line Wang-mendel Fuzzy Approach[J]. Information Sciences, 2021, 551: 113-127.
- [11] Zhou Ta, Chung F L, Wang Shitong. Deep TSK Fuzzy Classifier with Stacked Generalization and Triplely Concise Interpretability Guarantee for Large Data[J]. IEEE Transactions on Fuzzy Systems, 2017, 25(5): 1207-1221.
- [12] Zhang Yuanpeng, Hisao Ishibuchi, Wang Shitong. Deep Takagi-sugeno-kang Fuzzy Classifier with Shared Linguistic Fuzzy Rules[J]. IEEE Transactions on Fuzzy Systems, 2018, 26(3): 1535-1549.
- [13] Qin Bin, Yusuke Nojima, Hisao Ishibuchi, et al. Realizing Deep High-order TSK Fuzzy Classifier by Ensembling Interpretable Zero-order TSK Fuzzy Subclassifiers[J]. IEEE Transactions on Fuzzy Systems, 2021, 29(11): 3441-3455.
- [14] Gu Suhang, Chung F L, Wang Shitong. A Novel Deep Fuzzy Classifier by Stacking Adversarial Interpretable TSK Fuzzy Sub-classifiers with Smooth Gradient Information[J]. IEEE Transactions on Fuzzy Systems, 2020, 28(7): 1369-1382.
- [15] Wang Yuangang, Liu Haoran, Jia Wenjuan, et al. Deep Fuzzy Rule-based Classification System with Improved Wang-mendel Method[J]. IEEE Transactions on Fuzzy Systems, 2022, 30(8): 2957-2970.
- [16] Yin Rui, Pan Xuejun, Zhang Liyong, et al. A Rule-based Deep Fuzzy System with Nonlinear Fuzzy Feature Transform for Data Classification[J]. Information Sciences, 2023, 633: 431-452.
- [17] Yong Hongwei, Huang Jianqiang, Meng Deyu, et al. Momentum Batch Normalization for Deep Learning with Small Batch Size[C]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 224-240.
- [18] Bergstra J, Bengio Y. Random Search for Hyperparameter Optimization[J]. The Journal of Machine Learning Research, 2012, 13(1): 281-305.
- [19] Wu Dongrui, Yuan Ye, Huang Jian, et al. Optimize TSK Fuzzy Systems for Regression Problems: Minibatch Gradient Descent with Regularization, DropRule, and AdaBound (MBGD-RDA) [J]. IEEE Transactions on Fuzzy Systems, 2020, 28(5): 1003-1015.
- [20] Genuer R, Poggi J M, Genuer R, et al. Random Forests [M]. [S.l.]: Springer International Publishing, 2020.
- [21] Abdullah Elen, Selçuk Baş, Cemil Közkurt. An Adaptive Gaussian Kernel for Support Vector Machine[J]. Arabian Journal for Science and Engineering, 2022, 47(8): 10579-10588.
- [22] Specht D F. Probabilistic Neural Networks[J]. Neural Networks, 1990, 3(1): 109-118.
- [23] Zhou Shusen, Chen Qingcai, Wang Xiaolong. Fuzzy Deep Belief Networks for Semi-supervised Sentiment Classification[J]. Neurocomputing, 2014, 131: 312-322.
- [24] Deng Yue, Ren Zhiqian, Kong Youyong, et al. A Hierarchical Fused Fuzzy Deep Neural Network for Data Classification[J]. IEEE Transactions on Fuzzy Systems, 2017, 25(4): 1006-1012.
- [25] Gu Suhang, Vong C M, Wong P K, et al. Fast Training of Adversarial Deep Fuzzy Classifier by Downsizing Fuzzy Rules with Gradient Guided Learning[J]. IEEE Transactions on Fuzzy Systems, 2022, 30(6): 1967-1980.